

基于改进YOLOv10n的葡萄叶片病害检测算法的研究

罗 乐, 余 洪, 袁傲祥

重庆三峡科技大学计算机科学与工程学院, 重庆

收稿日期: 2026年9月3日; 录用日期: 2026年9月30日; 发布日期: 2026年10月13日

摘 要

葡萄种植过程中, 葡萄叶片病害在田间环境中一般会存在目标小、背景复杂、遮挡多等特征, 并且现有的检测模型大多存在着参数量大、边缘部署难等问题。本文以YOLOv10n为基础, 在此基础上提出一种轻量化的改进模型YOLOv10n-SH。该模型先用HGStem代替原来的浅层特征提取结构来减小高分辨率阶段的计算负担并且保留细节信息, 然后加入由HGBlock和深度可分离卷积组成的特征提取模块, 在保证参数量的同时提高主干网络的表达能力, 同时在主干网络的三个特征层引入层次自适应融合模块HAFB, 对C2f主路特征与HGBlock分支特征进行自适应对齐与加权融合, 替代原有的拼接融合方式, 从而增强小目标病斑的检测能力。实验结果表明, 在自建葡萄叶片病害数据集上, 与基线模型相比, YOLOv10n-SH的mAP@0.5达到97.7%, 提高了2个百分点, 参数量由2.3 M降至1.50 M, 计算量由6.7 GFLOPs降至5.9 GFLOPs, 具有一定的应用价值。

关键词

葡萄叶片病害, 目标检测, YOLOv10n, 特征提取

Research on Grape Leaf Disease Detection Algorithm Based on Improved YOLOv10n

Le Luo, Hong Yu, Aoxiang Yuan

School of Computer Science and Engineering, Chongqing Sanxia University of Science and Technology, Chongqing

Received: September 3, 2026; accepted: September 30, 2026; published: October 13, 2026

Abstract

During grape cultivation, leaf diseases generally exhibit characteristics such as small targets, complex

backgrounds, and frequent occlusions in the field environment. Existing detection models often suffer from large parameter sizes and difficulty in edge deployment. Based on YOLOv10n, this paper proposes a lightweight improved model, YOLOv10n-SH. The model replaces the original shallow feature extraction structure with HGStem to reduce computational load at the high-resolution stage while retaining detailed information. It then incorporates a feature extraction module composed of HGBlock and depthwise separable convolutions, enhancing the backbone network's expressive capability while maintaining the parameter count. Additionally, a hierarchical adaptive fusion module (HAFB) is introduced in three feature layers of the backbone network to adaptively align and weight the C2f main path features with the HGBlock branch features, replacing the previous concatenation fusion approach, thereby enhancing the detection capability for small disease spots. Experimental results on a self-built grape leaf disease dataset indicate that compared to the baseline model, YOLOv10n-SH achieves an mAP@0.5 of 97.7%, an increase of 2 percentage points, reduces the parameter count from 2.3 M to 1.50 M, and the computational load from 6.7 GFLOPs to 5.9 GFLOPs, demonstrating certain practical value.

Keywords

Grape Leaf Disease, Object Detection, YOLOv10n, Feature Extraction

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

葡萄是我国重要的经济作物,但是生长过程中容易受到黑腐病、霜霉病等病害的侵袭,造成叶片病变、光合能力降低,严重影响产量和品质[1]。传统的识别依靠经验,效率低,容易受到光照、主观因素的影响,不能满足大规模果园连续监测的要求。

近年来,随着深度学习的迅速发展,深度学习已广泛应用于农作物病害的识别。何东健等基于改进残差网络实现了田间葡萄霜霉病的自动分级[2],验证了深度学习在病害识别中的有效性;刘广等则将 YOLOv3 引入葡萄叶部病害检测[3],说明了单阶段检测算法在病害识别领域的高效性。边缘部署的迫切需求,使得模型轻量化成为研究热点,公徐路等以改进 YOLOv5s 为基础,融合 ShuffleNet v2 与注意力机制[4],实现了苹果叶片小目标病害的轻量化检测。在葡萄病害的研究中,冀常鹏等提出 CMS-YOLOv8n 模型,通过多尺度特征融合提升了叶片病害检测精度[5];范明超等则针对小病斑难题设计了 YOLOv8n-Grape,增强了对微小病斑的感知能力[6]。然而,这些研究对浅层的高分辨率特征提取、多尺度融合以及小目标病斑召回等方面还存在着一定的不足之处。本研究针对以上不足之处,提出 YOLOv10n-SH 模型。

本研究提出的改进模型 YOLOv10n-SH 算法主要工作有三个:1) 用 HGStem 代替原来的 Stem 来减少浅层计算量并且保留细粒度信息,2) 把 HGBlock 和深度可分离卷积结合起来形成轻量级主干,3) 在主干网络的三个特征层设计 HAFB 模块,对 C2f 主路特征与 HGBlock 分支特征进行自适应对齐与加权融合,替代原有的拼接融合方式。

2. 材料与方

2.1. 数据集的来源与构建

本研究共收集了 5 个叶片分类,分别为健康(Healthy)叶片、黑腐病(Black_rot)叶片、霜霉病

(downey_mildew)叶片、叶枯病(Leaf_blight)叶片、衰枯病(Esca)叶片。为了更好地将数据集应用于算法中，对数据集进行了剪裁处理，以确保所有样本图像的像素一致性，经过图像处理后，所有图像分辨率像素均为 640×640 ，经过筛选后，每个分类选择 1000 张图像，最终获得 5000 张有效图像，随后使用 labeling 对数据集进行人工标注，标注格式为 txt，为了保持试验数据的随机性，本试验按照分类随机将数据集划分为训练集、验证集和测试集，比例为 7:2:1。为了增强数据的多样性和模型的鲁棒性，本实验将训练集图像进行旋转、翻转、局部放大、亮度及暗度调整等数据增强工作使训练集图像扩充到 17,500 张。部分数据集样本如图 1 所示。



Figure 1. Partial dataset samples

图 1. 部分数据集样本

2.2. 实验平台

实验在以下环境中进行：Intel Xeon CPU + NVIDIA RTX 4090 GPU，24GB 显存，Ubuntu 20.04 系统，PyTorch 2.0，CUDA 11.8。训练参数：batch size = 50，初始学习率 0.01，优化器 SGD。

2.3. 评价指标

为了综合反映轻量化处理对模型的影响，选取了 4 个模型识别性能指标、2 个计算性能指标和模型权重大小来评价模型。模型识别性能指标有精确率(precision, P)、召回率(recall, R)、IoU 阈值为 0.5 时的平均精度均值，记作 mAP0.5、IoU 阈值 0.5 到 0.95 之间 10 个 mAP 值的平均值，记作 mAP 0.5~0.95；计算性能指标有参数量(parameters)、浮点数计算量(GFLOPs)，相关指标公式如下(1)~(3)所示：

$$\text{精确率: } P = \frac{TP}{TP + FP} \quad (1)$$

$$\text{召回率: } R = \frac{TP}{TP + FN} \quad (2)$$

$$\text{平均精度值: } mAP = \frac{\sum_{i=1}^n AP_i}{n} \quad (3)$$

(1)、(2)、(3)式中，FP 为错误预测的正样本数，FN 表示错误预测的负样本数，TP 表示正确预测的正样本数。AP_i 反映目标检测对单个类别的准确性。

3. 模型与训练

3.1. YOLOv10n 算法模型

YOLOv10 是由清华大学多媒体智能组于 2024 年提出[7]，该模型在保持单阶段端到端检测框架的基础上，加入了一致双重分配策略和 NMS-free 训练方式，在消除非极大值抑制后处理开销的同时，也考虑到了检测精度和推理效率[7]。YOLOv10 的网络结构仍由输入端、骨干网络、颈部网络和检测头四部分组成，并提供 n、s、m、l、x 五种尺度配置。随着模型规模增大，网络深度与宽度逐级递增，残差模块与注

意力模块数量相应增加，模型精度随之提升，但参数量与计算量也显著增加。其中，YOLOv10n 作为最轻量级版本，官方参数量约为 2.3 M，计算量约为 6.7 GFLOPs，在 NVIDIA T4 GPU 上的推理延迟约为 1.84 ms，适合资源受限的边缘端部署[7]。在复杂农业实时监测环境下，模型太大容易造成响应迟缓，从而降低系统的实用性，因此本研究选取 YOLOv10n 作为基线模型，进行轻量化研究，在保证精度的基础上进一步减少计算负担，满足智慧葡萄园边缘设备部署的要求。

3.2. 改进 YOLOv10n 算法模型

本文基于 YOLOv10n 算法提出轻量化葡萄叶片病害检测模型 YOLOv10n-SH，结构图如图 2 所示。首先用 HGStem 代替 6×6 Conv，分两级 3×3 卷积，避免 6×6 大核造成的访存不友好；其次引入 HGBlock 和 DWConv 混合模块，在保持 C2f 梯度流优势的基础上使 FLOPs 下降 20%到 30%；最后在主干网络的三个特征层引入 HAFB 模块，对 C2f 主路特征与 HGBlock 分支特征进行自适应对齐与加权融合，替代原有的 Concat 拼接融合方式，在保持相近计算开销的同时使不同来源特征的对齐更加精细。改进后的模型结构图如下图 2 所示。




Figure 2. YOLOv10n-SH model structure diagram
图 2. YOLOv10n-SH 模型结构图

1) 高效起始模块 HGStem

原 YOLOv10n 的 Stem 仅将 640×640 下采样至 320×320 ，后续层仍需在 320^2 高分辨率上运算，早期计算量巨大。本研究采用 HGStem [8]替代原始 Stem，通过级联下采样与多分支设计降低浅层开销。如

图 3 所示，输入先经 3×3 卷积(步长为 2)将空间维度减半，随后送入双分支：一支为两个连续 2×2 深度卷积提取小尺度特征，另一支为步长 1 的最大池化保留基本信息；两支输出拼接后，再经 3×3 卷积进一步下采样，最后以 1×1 卷积调整通道数。该模块在显著降低早期计算复杂度的同时，最大程度保留了病斑边缘与纹理等细粒度信息。




Figure 3. Internal structure of HGStem
图 3. HGStem 内部结构

2) HGBlock 与 DWConv 混合模块

主干网络里我们用 HGBlock [8]-[10]和 DWConv 搭建了一个混合特征提取单元。HGBlock 是从 CSP-Net 和 GhostNet 里借鉴过来的轻量残差块，内部用 GhostConv 生成冗余特征图来压缩卷积开销，再通过 Channel Shuffle 打乱通道顺序，让不同分支的信息充分混起来[2]；同时还嵌入了 SE 注意力，按通道重要性动态加权。DWConv 则把标准卷积拆成两步：先逐通道做 depthwise 卷积，再用 1×1 pointwise 卷积混合通道，计算量降得比较明显。我们把 3×3 和 5×5 的核跟这两种操作结合起来，小病斑边缘和大面积坏死区域都能覆盖到。这样整体比常规卷积轻不少，但特征多样性和判别力保留得住，给后续检测提供了一个既轻又强的特征基础。

3) HAFB

HAFB 用于对齐、融合并校准不同主干层的异源特征[11], 避免空间与语义差异导致的冲突。执行过程分三步: 首先, 低分辨率特征经轻量 DWConv 上采样, 高分辨率特征经 stride-2 DWConv 下采样, 统一至相同分辨率; 其次, 对齐特征通道拼接后送入双支路, 融合支路以 1×1 分组卷积压缩通道, 权重支路通过全局平均池化与 1×1 卷积生成空间融合权重, 动态调节各位置信息比例; 最后, 以 Sigmoid 激活的 1D 向量对两路输出逐通道加权求和, 实时抑制冗余通道、增强关键语义。该闭环设计有效消除层间差异, 将多尺度信息高效聚合, 为检测头提供判别力更强的特征表示。

4. 实验结果分析

4.1. 不同模块改进消融实验对比

为了验证不同模块的有效性, 本研究以 YOLOv10n 作为基础模型进行消融实验。实验通过 mAP50、mAP50-95、Precision (P)、Recall (R)、参数量、计算量等评价指标进行对比分析, 各模块实验结果如表 1 所示。

Table 1. Ablation experiment

表 1. 消融实验

模块	mAP@0.5/%	mAP@0.5-0.95/%	P/%	R/%	参数量/M	计算量/GFLOPs
YOLOv10n	95.7	81.8	98.4	94.9	2.3	6.7
YOLOv10n + HGStem	95.9	71.7	94.8	92.5	1.84	5.7
YOLOv10n + HGBLOCK	96.9	84.1	98.6	94.5	1.94	5.1
YOLOv10n + HAFB	97.0	86.2	98.7	95.4	3.72	8.6
YOLOv10n + HGStem + HGBLOCK	96.8	82.7	98	95.2	1.43	4.0
YOLOv10n + HGStem + HAFB	96.4	84.1	94.0	94.5	1.68	4.5
YOLOv10n + HGBLOCK + HAFB	97.4	85.6	98.9	95.5	1.8	6.1
YOLOv10n-SH	97.7	89.1	99.7	96.9	1.5	5.9

由表 1 可见, YOLOv10n 基线模型的 mAP@0.5 和 mAP@0.5:0.95 分别为 95.7%和 81.8%。加入 HGBlock 后, 模型的 mAP@0.5 提升至 96.9%, mAP@0.5:0.95 提升至 84.1%, 同时参数量由 2.3 M 降至 1.94 M, GFLOPs 由 6.7 降至 5.1, 说明 HGBlock 能够在降低模型复杂度的同时提升特征提取能力。单独加入 HAFB 之后, 模型的 mAP@0.5、mAP@0.5:0.95 分别提高到了 97.0%、86.2%, 比基线模型有提高, 说明自适应跨层特征融合可以加强模型的多尺度特征表达能力。但是 HAFB 单独使用时模型参数量和计算量都会增大, 说明该模块虽然可以提高检测精度, 但是也会带来一些额外的计算开销。最终, YOLOv10n-SH 综合采用 HGStem、HGBlock 和 HAFB, 取得了最优检测结果。模型的 mAP@0.5 为 97.7%, mAP@0.5:0.95 为 89.1%, Precision 和 Recall 分别为 99.7%和 96.9%。与基线模型相比, mAP@0.5 提高 2.0 个百分点, mAP@0.5:0.95 提高 7.3 个百分点; 参数量减少 0.8M, 计算量减少 0.8GFLOPs。结果表明各个改进模块之间存在一定的互补性, 可以共同提高模型的检测精度以及轻量化程度。

4.2. 不同模型对比试验

为进一步验证 YOLOv10n-SH 的检测性能, 将其与 RT-DETR、YOLOv5n、YOLOv8n、YOLO11 和 YOLO26 等模型进行对比。所有模型应在相同数据集划分、输入尺寸、训练轮次和评价标准下进行训练与测试, 实验结果如表 2 所示。

Table 2. Comparison test
表 2. 对比试验

模型	mAP@0.5/%	mAP@0.5-0.95/%	P/%	R/%	参数量/M	计算量/GFLOPs
RT-DETR	83.1	78.4	85.5	82.4	67.5	108.2
YOLOv5n	89.7	65.8	81.5	79.9	5.4	7.5
YOLOv8n	92.1	83.6	84.3	82.6	6.3	8.3
YOLO11	88.9	84.4	83.7	83.1	5.1	7.2
YOLO26	91.2	83.7	84.5	83.6	5.2	6.7
YOLOv10n-SH	97.7	89.1	99.7	96.9	1.5	5.9

从表 2 可以看出, YOLOv10n-SH 的各项检测精度指标都比对比模型好。其中, YOLOv10n-SH 的 mAP@0.5 达到 97.7%, 较 RT-DETR、YOLOv5n、YOLOv8n、YOLO11 和 YOLO26 分别提高 14.6、8.0、5.6、8.8 和 6.5 个百分点; mAP@0.5:0.95 达到 89.1%, 同样取得最高结果。在模型复杂度方面, YOLOv10n-SH 的参数量仅为 1.50 M, 低于其他对比模型; GFLOPs 为 5.9, 仅高于部分轻量化模型的理论计算量, 但低于 RT-DETR 和 YOLOv8n 等模型。综合检测精度以及模型复杂度可知, YOLOv10n-SH 在本数据集集中取得了较好的精度和效率之间的平衡。

5. 结论

本文针对葡萄叶片病害检测中模型精度低、计算量大、边缘部署难等提出一种改进的轻量化 YOLOv10n 检测模型 YOLOv10n-SH。该模型用 HGStem 优化浅层特征提取过程, 用 HGBlock 和深度可分离卷积降低模型复杂度, 在主干网络中用 HAFB 增强主路特征与分支特征的融合能力。

实验结果表明, YOLOv10n-SH 在葡萄叶片病害数据集上的 Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 分别达到 99.7%、96.9%、97.7%和 89.1%。与 YOLOv10n 基线模型相比, 改进模型的 mAP@0.5 提高 2.0 个百分点, mAP@0.5:0.95 提高 7.3 个百分点, 参数量由 2.3M 降至 1.50 M, GFLOPs 由 6.7 降至 5.9。从结果可以看出, YOLOv10n-SH 可以减小模型的参数量和计算量来提高葡萄叶片病害检测精度, 有一定的边缘部署应用价值。

后续的研究会增大数据集的规模, 加入不同地区、不同生育阶段以及复杂自然环境下的葡萄叶片图像, 在真实的嵌入式设备上做推理速度、功耗和跨场景泛化能力的测试, 来检验模型在实际智慧葡萄园中的应用效果。

尽管 YOLOv10n-SH 在自建数据集上取得了较好的检测效果, 但本研究仍存在以下局限: (1) 数据集规模为 5000 张图像, 且采集区域相对集中, 背景较为单一, 未充分覆盖真实田间环境中的光照突变、叶片遮挡、风雨扰动等复杂动态背景, 模型的跨场景泛化能力尚需进一步验证; (2) 实验仅在服务器 GPU 平台上评估了检测精度与模型复杂度, 尚未在真实的嵌入式边缘设备上对推理速度、功耗和长时间运行稳定性进行实测; (3) 健康叶片与部分病害早期症状在表观上较为相似, 模型对早期、微弱病斑的细粒度判别能力仍有提升空间。

后续研究将从以下方向展开: (1) 扩充数据集规模与多样性, 纳入不同地区、不同生育阶段及复杂自然田间环境下的葡萄叶片图像, 并引入对抗样本与域随机化策略提升模型鲁棒性; (2) 将模型量化和知识蒸馏等压缩技术应用于 YOLOv10n-SH, 在真实嵌入式设备上开展推理速度、功耗与跨场景泛化能力的系统测试; (3) 探索 RGB 图像与多光谱、气象信息等多模态数据的融合检测方法, 进一步提升对早期、微小病斑的识别能力, 为实际智慧葡萄园的边缘部署应用奠定基础。

参考文献

- [1] 徐虹, 李林峰, 杨昊, 等. 基于深度学习的植物叶病斑精细化分割方法[J]. 沈阳农业大学学报, 2025, 56(1): 92-107.
- [2] 何东健, 王鹏, 牛童, 等. 基于改进残差网络的田间葡萄霜霉病病害程度分级模型[J]. 农业机械学报, 2022, 53(1): 235-243.
- [3] 刘广, 胡国玉, 古丽巴哈尔·托乎提, 等. 基于改进 YOLOv3 的葡萄叶部病虫害检测方法[J]. 微电子学与计算机, 2023, 40(2): 110-119.
- [4] 公徐路, 张淑娟. 基于改进 YOLOv5s 的苹果叶片小目标病害轻量化检测方法[J]. 农业工程学报, 2023, 39(19): 175-184.
- [5] 冀常鹏, 佐永吉, 代巍. 基于 CMS-YOLOv8n 的葡萄叶片病害检测[J]. 沈阳农业大学学报, 2025, 56(3): 95-105.
- [6] 范明超, 张和群, 踪姿艳, 等. 基于 YOLOv8n-Grape 的葡萄叶片病害小目标检测[J]. 江苏农业科学, 2025, 53(9): 199-207.
- [7] Wang, A., Chen, H., Liu, L., *et al.* (2024) YOLOv10: Real-Time End-to-End Object Detection. <https://arxiv.org/abs/2405.14458>
- [8] Zhao, Y., Lv, W., Xu, S., Wei, J., Wang, G., Dang, Q., *et al.* (2024) DETRs Beat YOLOs on Real-Time Object Detection. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 16-22 June 2024, 16965-16974. <https://doi.org/10.1109/cvpr52733.2024.01605>
- [9] Wang, C.Y., Mark Liao, H.Y., Wu, Y.H., Chen, P., Hsieh, J. and Yeh, I. (2020) CSPNet: A New Backbone That Can Enhance Learning Capability of CNN. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Seattle, 14-19 June 2020, 1571-1580. <https://doi.org/10.1109/cvprw50498.2020.00203>
- [10] Han, K., Wang, Y., Tian, Q., Guo, J., Xu, C. and Xu, C. (2020) GhostNet: More Features from Cheap Operations. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 1577-1586. <https://doi.org/10.1109/cvpr42600.2020.00165>
- [11] 高雪, 袁飞, 霍艳飞. 基于改进 DEIM 的印刷电路板缺陷检测算法[J]. 液晶与显示, 2026, 41(5): 700-716.